

Модели адаптивной навигации в учебной гиперсреде

Предлагается модель навигации в учебной гиперсреде, обеспечивающая адаптацию сценариев обучения и контроля к имеющимся знаниям обучаемого и целям обучения. Адаптация осуществляется на основе построения дидактического образа знаний и учета логических зависимостей элементов учебной гиперсреды. Сценарий обучения содержит избыточную последовательность элементов гиперсреды, которые необходимо изучить. Сценарий контроля содержит наиболее сложные вопросы из тех, на которые обучаемый в состоянии ответить.

Одним из основных недостатков современных систем автоматизированного обучения является низкая динамическая адаптивность содержания предлагаемых учебных материалов к имеющимся знаниям и целям обучаемого. Эта проблема может быть решена с использованием интеллектуальных обучающих систем (ИОС) в виде адаптивных учебных гиперсред (АУГС) [1]. Их преимущества состоят в простоте формирования модели предметной области при создании курса непрограммирующими преподавателями и возможности адаптации к обучаемому в режиме обучения.

Гиперсреда обычно представляется множеством гипертекстовых статей – кадров, между которыми установлены ассоциативные гипертекстовые связи, и используется свободный порядок навигации путем переходов по этим связям. Адаптация в гиперсреде состоит в ограничении видимости отдельных элементов кадров и возможностей навигации. По сравнению с ИОС других типов АУГС используют упрощенные модели обучаемого и методики обучения. Повышение их эффективности возможно за счёт применения методов искусственного интеллекта, в частности при создании базы знаний о предметной области и о методиках обучения.

С целью решения указанной проблемы в статье предлагается формализация структуры гиперсреды путем выделения различных типов кадров и связей между ними в зависимости от их дидактического статуса и от особенностей применения в процессе обучения. На этой основе построены модели адаптивной навигации в учебной гиперсреде, позволяющие учитывать логические зависимости и дидактические характеристики элементов учебного курса, а также текущий и целевой уровень знаний обучаемого. В предлагаемом подходе реализуется управляемая навигация, при которой порядок переходов определяется сценарием обучения – последовательностью кадров, которая учитывает заданную преподавателем логику изложения материала и состояние знаний обучаемого. Сценарий строится на основе гипертекстовой базы знаний и выбранной модели навигации, а затем динамически адаптируется к изменениям модели обучаемого.

Обзор существующих моделей навигации в гиперсреде

В процессе автоматизированного обучения необходима динамическая адаптация состава учебного курса к изменениям знаний обучаемых путем изменения уровня сложности и объема предъявляемой учебной и контролирующей информации. Для реализации

такой адаптации требуется разработать формальное представление состояния знаний обучаемого и знаний, изложенных в кадре учебной гиперсреды, а также представление правил отбора учебных материалов, соответствующих состоянию знаний обучаемого.

Учебные материалы гиперсреды должны быть структурированы по темам и упорядочены по последовательности изучения, между ними имеются логические, смысловые, причинно-следственные и другие связи. Формальное представление знаний системы об изучаемой предметной области (о её объектах, процессах и закономерностях и их взаимосвязях) назовем *предметными знаниями*. В состав предметных знаний входят также контрольные задания и знания о методах их выполнения. Для автоматизированного планирования процесса обучения необходимы метазнания – описание свойств учебных материалов, перечень требуемых предварительных знаний и ожидаемый эффект от обучения.

Для организации учебных материалов в ИОС используются различные подходы: от полнотекстовых баз данных или гипермедиа-технологии до баз знаний и экспертных систем. Предметные знания в ИОС чаще представляются моделями на основе семантических сетей или фреймов, что позволяет существенно интеллектуализировать обработку запросов и ведение диалога с обучаемым [2]. Однако создание БЗ до настоящего времени является достаточно трудоемким и дорогостоящим процессом, требующим высокой квалификации разработчиков.

Методы гипертекстового моделирования предметной области являются менее трудоемкими. Известно, что гипертекстовая технология возникла как результат изучения механизмов памяти и процессов создания текстовых документов путём упорядочения и структуризации сети идей, представляемых автором гипертекста [3], [4]. Эта технология близка по целям исследования к теориям обучения и когнитивной психологии и является наиболее приемлемой из существующих средств моделирования предметных знаний, а модель гипертекста рассматривается как обобщенная модель знаний в экспертно-обучающей системе [5]. Предметные знания в АУГС представляются в виде множества взаимосвязанных текстовых фрагментов, описывающих объекты предметной области. Различные подходы к формированию учебной гипертекстовой сети анализируются в [6].

В настоящее время актуальным является решение задач автоматизации процессов создания гипертекста из текста, в частности, задач *категоризации* – сегментации, разбиения текста на фрагменты и тематические разделы и *линеаризации* – выявления связей различных типов между полученными фрагментами и их упорядочения. Возможно выделение в гипертексте структурных элементов трех уровней: ключевых слов и понятий, тезисных предложений и текстов. Следуя [6], уровень слов и предложений будем называть *микроуровнем*, а уровень текстов, соответственно, – *макроуровнем*.

Применительно к обучающим системам разработаны различные методики анализа и оптимизации гипертекстовой сети, а также категоризации ее элементов [7-14]. В качестве формальных признаков категоризации на микроуровне могут выступать критерии семантической близости [3], критерий монотематичности [7], статистический критерий [4]. Категоризация на макроуровне может осуществляться на основе статистического критерия длины кратчайшего пути [8], критерия насыщенности множества текстов [5], формальных правил построения графа содержания [9]. Для выявления ключевых понятий на микроуровне предлагается использование следующих методов: многомерное шкалирование (анализ попарных связей понятий предметной области), выявление точек сгущения понятий – «аттракторов», психосемантические методики [10].

В [11] предлагается модель предметных знаний в виде иерархической логической структуры обучающих воздействий на основе дидактических методов структурирования учебного материала, первоначально предложенных В.П. Беспалько. Знания предметной области разбиваются на иерархические уровни разделов и подразделов. В [12] на основе теории формального концептуального анализа предлагается представление предметной

области в виде множества концептуальных решеток разделов предметной области. Концептуальная решетка задается диаграммой Хассе в виде сети узлов, соответствующих множествам объектов, которые обладают некоторым множеством свойств. На сети определено отношение порядка, причем родительский узел включает все объекты своих потомков и обладает всеми свойствами своего родителя. Для детального структурирования гипертекстовых учебных материалов применяются алгоритмы объектно-структурного анализа «ОСА-гипер» [10], используемые в инженерии знаний. Соответствующий метод построения и последовательного наполнения структуры гипертекста [13] предполагает выделение в гипертексте структурных элементов на микро- и макроуровне. Между элементами устанавливаются гиперсвязи, отражающие смысловые связи типа понятие-тезис, тезис-текст, текст-текст. Из элементов каждого уровня строится семантическая сеть.

На каждом шаге динамически адаптивного обучения должны учитываться результаты всех предыдущих шагов, представленные в виде истории обучения и модели состояния знаний обучаемого [14]. Методы управления процессом обучения (навигации) в ИОС представляются в виде *методических знаний* – формализованного описания методики преподавания и оценки знаний, регламентирующей порядок изучения учебных материалов и требования к подготовке обучаемого.

Поддержка процесса навигации в учебной гипертекстовой среде имеет свои особенности, состоящие в необходимости учёта логических связей между кадрами для обеспечения принципа постепенного изучения и дополнительного различения кадров и связей по их образовательному статусу [15]. Поэтому статистические подходы к планированию последовательности кадров гиперсреды, подобные предложенному в [8], не могут быть применены.

Формальные правила навигации и линеаризации гиперсреды обсуждаются в [3], [4], [7], [15]. Наиболее распространенным походом к адаптивной навигации являются различные приемы адаптации ссылок путем определения их «полезности» [14], [16], [17]. Разработаны также методы и алгоритмы, позволяющие упорядочить кадры гиперсреды с целью получения связного текста (микроуровень) [3], [7], получения последовательности обучающих воздействий с постепенным усложнением изложения изучаемых понятий (макроуровень) [1], [4], [6], [18], выбора последовательности контролирующих воздействий [1], [19], [20]. Для представления методических знаний уместно применение продукционных правил, определяющих вид обучающих воздействий, их уровень сложности и порядок предъявления в зависимости от предыдущих успехов обучаемого [4]. Примеры методик с динамической адаптацией по процессу: логистическая модель с использованием формального аппарата структурированных сетей Петри [17], логические модели [21].

На основе разработанных методов активно изучаются возможности создания адаптивных обучающих гиперсред, появляются их прототипы: CALAT, InterBook, KBS, KnowledgeCT, Metalinks и др. [6], [14], [18], [20], [22]. Например, в ИОС KnowledgeCT используется модель процесса обучения в виде конечного автомата [19], [20]. Система позволяет обучаемому самостоятельно формировать стратегию обучения, задавая требуемые вероятности знания отдельных тематических разделов курса и вероятности применения разных методик обучения, представленных в программе.

Постановка задачи

Формальное представление модели обучаемого обозначим через λ , а множество всех таких моделей, допустимых гиперсредой, – через Λ . Правило формирования сценария зададим с помощью дидактической функции – частичного мультиотображения $\pi(\lambda)$: $\lambda \rightarrow O$, где $\lambda \in \Lambda$, а O – множество элементов сценария обучения, $O \subseteq F$. Данная функция устанавливает соответствие между текущей моделью обучаемого и множеством кадров, подлежащих изучению.

Тогда модель адаптивной навигации можно формально представить как кортеж $\langle \pi_1(\lambda_1), \dots, \pi_k(\lambda_k), \dots, \pi_K(\lambda_K) \rangle$, где π_k – дидактическая функция, а λ_k – модель некоторого обучаемого, используемая на k -м шаге ($k = 1, \dots, K; K \geq 1$) [1]. Каждый последующий шаг может отличаться от предыдущего моделью обучаемого (целью, состоянием знаний) и/или дидактической функцией. При этом модель обучаемого и функция π могут корректироваться автоматически на каждом шаге обучения на основе информации обратной связи.

Модель предметных знаний

Модель предметных знаний представлена в виде гипертекстовой базы знаний как множество F кадров и связей между ними трёх различных типов, формализованных в виде бинарных отношений: типичных гипертекстовых ассоциативных связей Σ , связей дидактической эквивалентности N , которые устанавливаются между множествами кадров, если в них изложены сведения относительно синонимичных понятий, а также связей логической зависимости Δ , представленных отношением порядка на множестве кадров F . Содержательно дидактически эквивалентными являются такие два множества кадров, изучение которых дает одинаковый результат. Если теоретический кадр t_2 логически зависит от t_1 , то к изучению t_2 можно приступить только при наличии знания материала из t_1 . Аналогично для кадров контроля.

Орграф $G_\Delta = (F, \Delta)$ отношения логической зависимости составляет основу модели предметных знаний. В нём выделяются подграфы тематических разделов. *Тематический раздел* – связный подграф $G_\Delta(R)$ графа G_Δ , индуцированный множеством $R \subseteq F$, имеющим наибольший (начальный) и наименьший (конечный) элементы относительно Δ . Раздел содержит множество вершин-кадров с исчерпывающей информацией по определенной теме, а также начальную вершину f_{B_R} с оглавлением или вводной частью и конечную вершину f_{E_R} с итоговой информацией.

Для каждой вершины в тематическом разделе выделяется соответствующий ей подраздел, как подграф зависимости графа этого раздела. *Подраздел, соответствующий вершине v* , – подграф G_v графа тематического раздела $G_\Delta(R)$, образованный множествами вершин и дуг всех трансцепей этого раздела, содержащих некоторую вершину $v \in R$. *Трансцепью* тематического раздела $G_\Delta(R)$ называется произвольная орцепь из начальной в конечную вершину этого раздела. Содержательно в подраздел входят те вершины, от которых зависит «возможность изучения» данной вершины, и те, которые в свою очередь зависят от её «изученности».

Тематическая полнота некоторого множества вершин, рекомендуемых для изучения, определяется путем проверки следующего условия насыщенности. Множество является насыщенным, если вся информация, необходимая для изучения любой вершины этого множества, содержится в вершинах самого этого множества. Пусть R – множество вершин изучаемого тематического раздела $G_\Delta(R)$, а V – подмножество R . Множество V является *насыщенным*, если для любых вершин $b \in R$ и $a \in V$, удовлетворяющих соотношению $(b, a) \in \Delta$, справедливо $b \in V$ и во множестве V нет вершин, эквивалентных b .

На основе предложенной модели гиперсреды разработаны модели навигации с адаптацией к уровню знаний обучаемого, к логической зависимости кадров гиперсреды и к дидактическому описанию кадров [1].

Модели адаптивной навигации

Модель навигации, адаптивной к логической зависимости

Адаптация к логической зависимости осуществляется в два этапа. На первом этапе происходит определение начального множества вершин $B = \{v \mid v \in F, \theta(v) = 1\}$, содержащих изученные теоретические кадры (правильно выполненные задания, вопросы), и множество A целевых вершин обучения или контроля ($B, A \in 2^F$). Состав данных множеств может быть задан явно преподавателем/обучаемым или определен автоматически исходя из данных о множестве понятий, которые обучаемый усвоил. В качестве модели обучаемого u_i при адаптации к логической зависимости примем пару подмножеств множества вершин гиперсреды $\lambda_0(u_i) = (B, A)$.

На втором этапе для обучения требуется отобрать множество вершин, которые следуют за вершинами из B относительно Δ и способствуют достижению целей из A , т.е. предшествуют A относительно Δ . Основой для адаптивного отбора таких вершин при построении сценария обучения является следующее понятие выводимости. Вершина непосредственно следует за некоторым насыщенным множеством, если при добавлении указанной вершины в это множество сохраняется свойство его насыщенности. Пусть V – насыщенное множество, а $c \notin V$ – произвольная вершина. Если множество $V \cup \{c\}$ является насыщенным, то считается, что вершина c непосредственно следует за множеством V .

В качестве модели базы знаний для управления навигацией, адаптивной к логической зависимости, используется ориентированный гиперграф порядка изучения $\mathcal{G} = (F, \mathcal{P})$, определённый на множестве F вершин графа логической зависимости. Каждая гипердуга из множества $\mathcal{P} = \{(\mathcal{B}, \mathcal{A}) \mid \mathcal{B}, \mathcal{A} \in 2^F, \mathcal{B} \cap \mathcal{A} = \emptyset\}$ задаётся упорядоченной парой непересекающихся подмножеств множества F , причём вершины правой части \mathcal{A} гипердуги непосредственно следуют за множеством вершин её левой части \mathcal{B} . Содержательно гипердуга устанавливает не только порядок изучения, но и «достаточность» знания множества вершин из левой части для перехода к изучению вершин из правой части. Тем самым обеспечивается адаптация к логической зависимости как отсутствие логических разрывов в изложении и корректное формирование альтернативных сценариев.

Выбор вершин при построении сценария с адаптацией к логической зависимости основывается на следующем понятии выводимости. Вершина a любого графа тематического раздела $G_\Delta(R)$ называется выводимой из произвольного множества вершин $V \subset R$, если $a \notin V$ и в гиперграфе $\mathcal{G} = (F, \mathcal{P})$ существует гипердуга $(\mathcal{B}, \mathcal{A}) \in \mathcal{P}$ такая, что $a \in \mathcal{A}$, $\mathcal{A} \neq \emptyset$, а $\mathcal{B} \subset V \cup \{f_{B_R}\}$, где f_{B_R} – начальная вершина раздела $G_\Delta(R)$. Обозначим факт выводимости как $V \dot{\vdash} a$.

Сценарий обучения, формируемый на основе гиперграфа порядка изучения, должен содержать все вершины соответствующего тематического раздела; иметь порядок следования вершин, который не нарушает отношения логической зависимости; а также в сценарии не должны присутствовать вершины из других тематических разделов, не принадлежащие изучаемому разделу. Для получения сценария с такими характеристиками в [5] разработаны требования представительности, корректности и непротиворечивости, которым должна удовлетворять структура гиперграфа. Гиперграф G называется: 1) *представительным*, если любая вершина любого тематического раздела, непосредственно следующая за произвольным насыщенным множеством вершин, выводима из этого множества; 2) *корректным*, если любая вершина любого тематического раздела, непосредственно не сле-

дующая за произвольным насыщенным множеством вершин этого раздела, не выводима из данного множества; 3) *непротиворечивым*, если для любого подмножества вершин V любого тематического раздела $G_{\Delta}(R)$ каждая вершина из множества $F \setminus R$ не выводима из множества V . В [5] также доказаны утверждения, формулирующие необходимые и достаточные условия выполнения этих требований, а также определены формальные критерии их проверки.

Построим модель навигации, осуществляющую выбор и логическое упорядочение предъявляемых вершин с учетом наличия у обучаемого знаний некоторого начального множества вершин. До начала обучения $\pi_0(\lambda_0) = B$. На $(k+1)$ -м шаге дидактическая функция запишется в виде $\pi_{k+1}(\lambda_{k+1}) = \{v' \mid v' \in F, \pi_k(\lambda_k) \not\in v'\}$. Функция $\pi_{k+1}(\lambda_{k+1})$ определяет множество кадров, которые выводимы из множества $\pi_k(\lambda_k)$, изученного обучаемым, и способствуют достижению цели A . Правило актуализации модели обучаемого имеет вид $\lambda_{k+1} = \{B \cup \pi_k(\lambda_k), A \setminus \pi_k(\lambda_k)\}$, где K – количество шагов обучения. Условие окончания обучения представляется как $\pi_K(\lambda_K) \supseteq A$.

На основе предложенных формализмов адаптации к логической зависимости кадров разработан метод и алгоритмы автоматизированного обучения, которые реализуют формирование учебной гиперсреды и управление процессом обучения. Гиперграф порядка изучения строится для каждого тематического раздела на основе отношения логической зависимости кадров, которое задаётся преподавателем в диалоговом режиме. В процессе формирования гиперграф программно проверяется на представительность и корректность. При наличии альтернативных подразделов проверяется непротиворечивость гиперграфа.

Алгоритм управления обучением с адаптацией к логической зависимости получает на входе множество изученных вершин раздела, целевую вершину и представительный, корректный и непротиворечивый гиперграф. Множество изученных вершин проверяется на насыщенность и определяется наиболее подходящий подраздел для продолжения обучения. Сценарий строится как множество всех вершин, непосредственно следующих за изученным множеством и предшествующих целевой вершине в рамках выбранного подраздела. Алгоритм позволяет выявлять имеющиеся пробелы в знаниях и выдавать рекомендации по их устранению.

Модель навигации с адаптацией к уровню знаний обучаемого

Модель навигации с адаптацией к уровню знаний обучаемого предполагает моделирование состояния знаний обучаемого отображением изученности $\theta: F \rightarrow \{0, 1, null\}$, которое определено на множестве вершин F и фиксирует знание или незнание информации или ответа на вопрос $f \in F$ некоторым обучаемым. Значение «1» соответствует знанию, «0» – незнанию информации или ответа на вопрос $f \in F$ некоторым обучаемым, а «null» означает, что «изученность f » ещё не определена.

В процессе оценки уровня знаний обучаемого по разделу $G_{\Delta}(R)$ рассматривается гипотеза $h(v)$ относительно знаний содержимого вершины v , принимающая следующие значения: h_1 – обучаемый *знает* тему, h_0 – обучаемый *тему не знает*.

В соответствии со значением гипотезы множество R вершин тематического раздела $G_{\Delta}(R)$ разбивается на два класса: множество $R_1 = \{v \mid v \in R, h(v) = h_1\}$ вершин с вопросами, на которые обучаемый, предположительно, сможет ответить, и множество $R_0 = \{v \mid v \in R, h(v) = h_0\}$ вершин с вопросами, на которые он не сможет ответить. Исходной информацией об обучаемом служит вероятность того, что он знает (сможет изучить) данную тему. Эта вероятность определяется, например, по оценкам в журнале. В качестве модели обучаемого u_i примем значение вероятности гипотезы h_1 : $\lambda_0(u_i) = P(h_1, u_i)$.

Задача адаптации к уровню знаний состоит в выборе для предъявления таких вершин v изучаемого раздела $G_{\Delta}(R)$, для которых после их изучения (выполнения задания) будет получена оценка знаний, соответствующая вероятности знаний данного обучаемого.

В качестве симптома, подтверждающего одно из значений гипотезы для выбранной вершины v' , используется результат $s(v')$ оценки знаний этой вершины (ответа на соответствующий вопрос), изменяющий значение изученности $\theta(v')$: $s(v') = s_1$ – обучаемый *подтвердил знание* и $\theta(v') = 1$, $s(v') = s_0$ – обучаемый *не подтвердил знание* и $\theta(v') = 0$.

Модель использует свойство графа логической зависимости, доказанное в [23] в виде следующего утверждения.

Утверждение. Если для произвольной пары вершин a и b справедливы соотношения $a \in R_1$ и $b \in R \setminus R_1$, то $(b, a) \notin \Delta$; если для любой пары вершин c и d справедливо $c \in R \setminus R_0$ и $d \in R_0$, то $(d, c) \notin \Delta$.

Если для некоторой вершины графа логической зависимости выяснилось, что обучаемый знает содержащийся в ней учебный материал, то все вершины, предшествующие ей относительно логической зависимости, также можно пометить как изученные. Аналогично неизученными считаются вершины, следующие за той, материал которой обучаемый не знает. Это позволяет автоматически доопределить отображение изученности. Адаптация к уровню знаний состоит в выборе наиболее сложного вопроса из числа тех, на которые обучаемый в состоянии ответить (в выборе для предъявления таких вершин v изучаемого раздела $G_{\Delta}(R)$, для которых после их изучения или выполнения соответствующего задания будет получена оценка знаний, соответствующая вероятности знаний данного обучаемого).

Процесс оценки уровня знаний так же, как и процесс выбора вопроса, соответствующего этому уровню, носят вероятностный характер. В связи с этим для выбора предъявляемой вершины v с вопросом используется эвристический критерий $\eta(v', P(h_1)) = \| R_v \mid P(h_1) - \mid R_1(v') \|$, равный разности математического ожидания количества известных обучаемому вершин в подразделе, соответствующем выбранной вершине, и числа вершин, которые предшествуют ей в графе логической зависимости. Наиболее соответствует уровню знаний обучаемого такая вершина, для которой значение этого критерия минимально.

Дидактическая функция, осуществляющая выбор предъявляемой вершины v' , для которой значение критерия соответствия η минимально, имеет вид $\pi_k(\lambda_k) = \{v' \mid \eta(v', \lambda_k) = \min_{v \in R} \eta(v, \lambda_k)\}$.

После предъявления вершины v' и получения результата ответа $s(v') = s'$ актуализируем модель обучаемого u_i следующим образом: $\lambda(u_i) = P(h_1 \mid s')$. Для этого оценим апостериорные вероятности исследуемых гипотез по формуле Байеса:

$$\pi_{i+1} = P(h_1 \mid s') = \pi_i \bar{b}, \quad \bar{b} = \frac{P(s' \mid h_1)}{\sum_{k=0}^1 P(h_k) P(s' \mid h_k)}.$$

Для принятия решения в пользу одной из гипотез относительно реального состояния знаний обучаемого используется метод Байеса, основанный на критерии минимума средних суммарных потерь, возникающих из-за неопределенности в оценке знаний. Пусть после предъявления v' получен результат s' оценки знаний, рассматриваемой как симптом в пользу одного из значений гипотезы. Принятие решения в пользу значения h_k на основании симптома s' обозначим как $\rho_k = \rho(s') = h_k$, где $k = 0, 1$. Функция потерь, возникающих при отнесении предъявленной вершины к классу ρ_k , в то время как она фактически принадлежит классу h_j (соответственно, $v' \in R_j$), определена как $\varphi_{kj} = \varphi(\rho_k \mid h_j)$ и задаётся

матрицей потерь

$$\|\Phi_{kj}\| = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}.$$

Математическое ожидание потерь, если принято решение ρ_k , равно $\Pi(\rho_k | s') = \sum_{j=0}^1 \Phi_{kj} P(h_k) \sum_{v \in R_i} P(s' | h_i)$, а суммарное математическое ожидание потерь (средние суммарные потери) равно $\Pi(\rho | s') = \sum_{k=0}^1 \sum_{j=0}^1 \Phi_{kj} P(h_k) \sum_{v \in R_i} P(s' | h_i)$, где $P(h_j)$ – априорная вероятность предъявления вершин j -го класса, а $P(s' | h_j)$ – условная вероятность симптома (полученной оценки знаний) при известном значении гипотезы, $j = 0, 1$.

Минимум потерь обеспечивается, если к классу R_1 изученных отнести те вершины, для которых условная вероятность наличия знаний выше условной вероятности их отсутствия: $P(h_1 | s') > P(h_0 | s')$. В случае, когда средние суммарные потери минимальны, процесс тестирования обучаемого по тематическому разделу будет оптимальным.

Предложенная модель обучения и контроля с адаптацией к уровню знаний обучаемого использована при реализации метода и алгоритмов автоматизированного контроля знаний. На входе алгоритма, управляющего процессом контроля знаний по определённой теме, задается априорная вероятность гипотезы о наличии знаний у обучаемого (полученная по оценкам в журнале), а также массив значений условных вероятностей результатов тестирования, вычисляемых после апробации тестов. На выходе – множества вершин R_1 с вопросами, которые обучаемый знает, и R_0 с вопросами, которые он не знает.

Данный метод и алгоритмы контроля обеспечивают существенное сокращение числа задаваемых обучаемому вопросов без потери качества оценки его знаний. Наименьшее число вопросов и, соответственно, время тестирования достигается при отсутствии разногласий между априорной оценкой знаний обучаемого и результатами тестирования. Метод особенно эффективен при входном контроле знаний, когда множество изученных вершин и цели обучения ещё не определены, а также при итоговом контроле по всему курсу.

Дидактически-ориентированная модель навигации

Дидактически-ориентированная модель навигации основана на моделировании понятийной структуры изучаемого предмета путём применения тезауруса и механизмов семантического индексирования в сочетании с дидактическими знаниями об уровнях изложения понятий и порядке их изучения [1].

Для формального представления дидактических характеристик учебного материала и состояния знаний обучаемого используем *дидактический образ состояния знаний* в виде множества значений уровня усвоения изучаемых понятий, измеряемых по некоторой шкале порядка. Шкалу порядка представим конечным упорядоченным множеством уровней усвоения $X = \langle null, x_1, \dots, x_j, \dots, x_{NX} \rangle$, где если $i < j$, то $x_i < x_j$ для любого $i, j \in \{1, \dots, NX\}$. Пустой элемент обозначается nul , $null < x_j$ для любого j .

Пусть U – множество обучаемых, а D – множество понятий предметной области и $N_D = |D|$. Зададим отображение σ , которое сопоставляет каждому понятию $d_n \in D$ уровень $r_{i_n} = r(u_i, d_n) = x_j$ его усвоения обучаемым u_i , $x_j \in X$. Дидактическим образом состояния знаний назовем результат отображения σ для состояния знаний обучаемого u_i : $\sigma_i = (r_{i_1}, r_{i_2}, \dots, r_{i_{N_D}})$. Дидактический образ состояния знаний можно использовать как единый набор признаков для описания как состояния знаний обучаемого, так и знаний, представленных в вершине гиперсреды. Множество всех возможных дидактических образов знаний, рассматриваемых системой, обозначим через S . Зададим отображение $\tau: F \rightarrow$

$S \times S$ множества учебных вершин F во множество пар дидактических образов. Обучающим воздействием вершины $v_k \in F$ назовем элемент отображения $\tau: \tau(v_k) = \tau_k = (\tau_k^i, \tau_k^o)$, где $\tau_k^i = (r_{k_1}^i, r_{k_2}^i, \dots, r_{k_{N_D}}^i)$ – условие предъявления, $\tau_k^o = (r_{k_1}^o, r_{k_2}^o, \dots, r_{k_{N_D}}^o)$ – результат изучения вершины, а $r_{k_n}^o, r_{k_n}^i$ – результирующий и начальный уровни изучения понятия d_n . Условие предъявления характеризует знания, которые требуются для перехода к изучению вершины, а результат изучения – знания, представленные в вершине.

Далее построим формальную модель обучаемого. Пусть S_A – все возможные целевые, а S_B – возможные начальные/текущие дидактические образы знаний обучаемого из S . Зададим отображение $\lambda: U \rightarrow S_B \times S_A$ множества обучаемых во множество всех возможных пар начального и целевого дидактических образов знаний обучаемого. В качестве модели обучаемого u_i примем элемент отображения $\lambda(u_i): \lambda(u_i) = (\sigma_b, \sigma_a)$, причем $\sigma_b = (r_{b_1}, r_{b_2}, \dots, r_{b_{N_D}})$ – текущий, $\sigma_a = (r_{a_1}, r_{a_2}, \dots, r_{a_{N_D}})$ – целевой дидактический образ знаний, а r_{b_n} и r_{a_n} – текущий и целевой уровни изучения понятия d_n , где $\sigma_b \in S_B$, $\sigma_a \in S_A$, $r_{a_n}, r_{b_n} \in X$. Модель обучаемого данного вида характеризует множество понятий, которые необходимо изучить на соответствующем уровне для достижения целей σ_a из S_A , имея состояние знаний σ_b из S_B .

Построим модель навигации, осуществляющую отбор предъявляемых вершин по результатам сопоставления множества понятий, изучаемых в вершине, и состояния знаний обучаемого. Введем функцию согласия $\phi_m(\tau_k, \lambda_k)$, фиксирующую факт увеличения уровня усвоения некоторого целевого понятия d_m после изучения τ_k : $\phi_m(\tau_k, \lambda_k) = 1$, если $r_{b_m} \leq r_{k_m}^o \leq r_{a_m}$, $r_{k_m}^o \neq null$, $r_{a_m} \neq null$, и $\phi_m(\tau_k, \lambda_k) = 0$ в противном случае, $m \in \{1, \dots, N_D\}$.

Критерий соответствия, вычисляющий количество целевых понятий, для которых увеличивается уровень усвоения после изучения исследуемой вершины, примет вид

$$\eta(v_k, \lambda_k) = \sum_{m=1}^{N_D} \phi_m(v_k, \lambda_k). \text{ Условие соответствия вершины цели обучения } \sigma_a: \eta(\tau_k, \lambda_k) \geq 1.$$

Для выбора вершины v' , наиболее соответствующей текущей модели обучаемого, используем дидактическую функцию вида $\pi(\lambda_k) = \{v' \mid \eta(v', \lambda_k) = \max_{v \in R} \eta(v, \lambda_k)\}$, $\lambda_k \in \Lambda$.

Заключение

Представленная модель предметных знаний учебной гиперсреды в виде множества взаимосвязанных кадров с учебной информацией отличается от известных выделением терминальных и нетерминальных кадров, наличием логического упорядочения и учётом дидактической эквивалентности кадров гиперсреды. Это позволяет строить дидактически обоснованные последовательности изучения информации и формализованно представлять альтернативные способы изучения учебного материала. Ограничение возможностей использования данной модели обусловлено трудоемкостью тематического упорядочения кадров гиперсреды.

Модель навигации в гиперсреде с адаптацией к логической зависимости кадров построена в виде представительного, корректного и непротиворечивого гиперграфа порядка изучения на множестве кадров гиперсреды. В модели использовано понятие выводимости, задающее формальные условия включения кадров в сценарий обучения в зависимости от состава множеств изученных и целевых кадров, зафиксированных в модели обучаемого. Предусмотрена оптимизация процесса формирования сценария обучения на основе формальных требований к гиперграфу.

Модель навигации с адаптацией к уровню знаний обучаемого основана на байесовском подходе обеспечения минимума средних суммарных потерь, обусловленных неправильной оценкой знаний. Особенность модели состоит в использовании эвристического критерия соответствия, по которому на каждом шаге процесса обучения выбирается для предъявления кадр, наиболее соответствующий уровню знаний обучаемого исходя из текущего значения вероятности наличия знаний у обучаемого. При выставлении оценки учитывается наличие неопределенности в оценке знаний. Вводится отображение изученности, которое автоматически доопределяется на поддереве, соответствующем текущей вершине, на основании выставленной оценки. Условно исключаются из множества вершин те, ответы на которые заведомо известны или неизвестны обучаемому. Данная модель позволяет сократить количество предъявляемых вопросов, а следовательно, и время тестирования без потери качества оценки знаний.

Дидактически-ориентированная модель навигации в учебной гиперсреде отличается наличием педагогического тезауруса, который структурирует информацию не только по изучаемым понятиям предметной области, но и по уровням их усвоения. Описание обучающего воздействия каждого кадра обеспечивает учёт требуемого уровня знаний обучаемого и является основой для описания методики формирования модели обучаемого по результатам работы с гиперсредой. Данная модель является формализацией существующих ручных методик формирования содержания обучения и позволяет автоматизировать начальный этап проектирования учебного материала в ЭОС. Обеспечивается возможность гибкого планирования обучения преподавателем путём диалогового ввода в декларативной форме информации о целях обучения в виде требований к знаниям изучаемых понятий. Данная модель является универсальной по отношению к форме представления информационных объектов, к методике распределения учебного материала по уровням изложения и к методике оценки знаний. Ограничение возможностей использования данной модели заключается в том, что дидактическое индексирование гиперсреды является трудоемким процессом.

Рассмотренные модели навигации не только разработаны теоретически, но и получили практическое воплощение в рамках создания программно-методических средств обучения и контроля.

Литература

1. Шибут М.С. Моделирование адаптивного процесса обучения с использованием гиперсреды // Информатика. – 2007. – № 4. – С. 48-58.
2. Интеллектуальные обучающие системы и виртуальные учебные организации: Монография / Под ред. В.В. Голенкова, В.Б. Тарасова. – Минск: Белорус. гос. ун-т информатики и радиоэлектроники, 2001. – 486 с.
3. Субботин М.М. Алгоритмическая навигация в гипертекстовой сети как способ генерации дискурсивных текстов // Изв. Рос. акад. наук. Сер. Теория и системы упр. – 1996. – № 2. – С. 158-161.
4. АНА! Version 2.0, more adaptation flexibility for authors / P. De Bra [etc.] // E-Learn 2002: Proc. of the World conf. on E-learning in corporate, government, healthcare a. higher education, Montreal, 15 – 19 oct. 2002 / Assoc. for the advancement of computing in education. – Norfolk, 2002. – P. 240-246.
5. Липницкий С.Ф., Шибут М.С., Ярмош Н.А. Гипертекстовая экспертно-обучающая система. I. Модель данных и знаний // Вест. Нац. акад. наук Беларусі. Сер. фіз.-мат. навук. – 1998. – № 3. – С. 111-114.
6. Murray T. Authoring intelligent tutoring systems: an analysis of the state of the art // Intern. j. of artificial intelligence in education. – 1999. – № 10. – P. 98-129.
7. Липницкий С.Ф., Ярмош Н.А. Моделирование интеллектуальных процессов в инженерных информационных системах. – Минск: Беларус. навука, 1996. – 222 с.
8. Никифоров И.С. Статистический подход в поддержке процесса навигации в гипермедиа системах. – Режим доступа: <http://inftech.webservis.ru/it/conference/scm/1999/session3/nikiforov.html>.

9. Соловов А.В. Моделирование структуры электронных образовательных ресурсов // Информационные технологии. – 2007. – № 3. – С. 43-49.
10. Гаврилова Т.А., Хорошевский В.Ф. Базы знаний интеллектуальных систем. – СПб.: Питер, 2000. – 384 с.
11. Морозевич А.Н., Комличенко В.Н., Гедранович В.В. Стратегия автоматизации управления познавательной деятельностью на основе информационной модели образовательного процесса // Информационные технологии. – 2000. – № 5. – С. 47-52.
12. Таран Т.А., Сирота С.В. Обучение понятиям в интеллектуальных обучающих системах на основе формального концептуального анализа // Искусственный интеллект. – 2002. – № 3. – С. 340-347.
13. Шикунев С.А. Метод построения учебного гипертекста по ключевым словосочетаниям // Вопросы Интернет-образования. – 2003. – № 10. – Режим доступа: http://center.fio.ru/vio/vio_10/cd_site/Articles/art_1_7.htm.
14. Brusilovsky P. Adaptive hypermedia // User modeling and user adapted interaction. – 2001. – Vol. 11, № 1-2. – P. 87-110.
15. Демин И.С. Гипертекстовые среды и обучение // Вестн. финансовой акад. – 2003. – № 4. – С. 71-76.
16. Соловов А.В. Моделирование навигации в электронных образовательных ресурсах // Информационные технологии. – 2007. – № 4. – С. 72-79.
17. Пантелеев Е.Р. Средства поддержки жизненного цикла Web-обучения в инструментальном комплексе // Информ. технологии. – 2007. – № 2. – С. 39-45.
18. Henze N. Adaptive hyperbooks: adaptation for project-based learning resources: diss. ... dr. der. Naturwissenschaften. – Hannover, 2000. – 95 p.
19. Астанин С.В., Калашникова Т.Г. Разработка индивидуальной модели поведения обучаемого в системе дистанционного образования // Перспективные информационные технологии и интеллектуальные системы. – 2001. – № 1. – С. 179-196.
20. Голец И.Н., Попов Д.И. Модель представления знаний в интеллектуальной системе дистанционного образования // Перспективные информационные технологии и интеллектуальной системы. – 2001. – № 3. – С. 135-138.
21. Бобков А.И., Тюрликова О.А. Построение стратегий классификации уровня знаний на основе графоаналитической модели // Кибернетика. – 1988. – № 5. – С. 109-112.
22. Authoring methods for the Web-based intelligent CAI system CALAT and its application to telecommunications service / M. Kiyama [etc.] // Artificial intelligence: Proc. of the 14th nat. conf., Providence, 27–31 July 1997/ Amer. assoc. for artificial intelligence. – Menlo Park, 1997. – P. 44-52.
23. Липницкий С.Ф., Шибут М.С., Ярмош Н.А. Метод автоматизированного контроля знаний в гипертекстовой среде // Вест. Нац. акад. наук Беларуси. Сер. техн. наук. – 2000. – № 1. – С. 86-89.

М.С. Шибут

Моделі адаптивної навігації у навчальному гіперсередовищі

Пропонується модель навігації у навчальному гіперсередовищі, яка забезпечує адаптацію сценаріїв навчання і контролю до наявних знань навчаного і цілей навчання. Адаптація здійснюється на основі побудови дидактичного образу знань і обліку логічних залежностей елементів навчального гіперсередовища. Сценарій навчання містить ненадмірну послідовність елементів гіперсередовища, які необхідно вивчити. Сценарій контролю містить найскладніші питання з тих, на які навчаний в змозі відповісти.

M.S. Shibut

Models of Adaptive Navigation in the e-Learning Hypermedia System

The model of navigation in the e-learning hypermedia system is offered, providing the training and control script adaptation to the level of learner knowledge and his learning aims. Adaptation is realized by construction of the image of didactic knowledge and taking into account the logical dependences of hypermedia elements. The training script contains irredundant sequence of hypermedia elements, which are necessary to study. The control script contains the most difficult questions, which learner can answer to.

Статья поступила в редакцию 24.07.2008.